

# Разработка технологии выбора информативной окрестности для моделирования текстурных изображений

Е.В. Бирюкова<sup>а</sup>, Р.А. Парингер<sup>а,б</sup>, Д.В. Кириш<sup>а,б</sup>, Н.С. Кравцова<sup>а</sup>

<sup>а</sup> Самарский национальный исследовательский университет имени академика С.П. Королева, 443086, Московское шоссе 34, Самара, Россия

<sup>б</sup> Институт систем обработки изображений РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН, 443001, ул. Молодогвардейская, 151, Самара, Россия

## Аннотация

В работе предлагается способ построения информативной окрестности для моделирования текстурных изображений. Для описания характерных особенностей текстур используются предположения, лежащие в основе модельного представления текстурных изображений, описываемые с использованием марковского случайного поля. Результаты проведенных экспериментальных исследований свидетельствуют о том, что применение разработанного подхода позволяет снизить размерность признакового пространства, не снижая при этом достоверность классификации.

Ключевые слова: модель марковского случайного поля; гауссовское марковское поле; текстурные изображения; матрица смежности; классификация; текстурный анализ; каузальная окрестность

## 1. Введение

Текстурный анализ широко распространён в обработке различных типов изображений, однако, несмотря на то, что ещё в 1979 году Харалик отметил, что методы различения текстур разрабатываются отдельно для каждого конкретного случая [1], нет ни чёткого определения текстуры, ни определённой концепции в решении задач анализа текстурных изображений.

Хаиндл писал, что текстура – это свойство поверхности, представляющее пространственную информацию, содержащуюся на поверхности объекта [2].

В литературе описаны три подхода к анализу текстур [1, 3, 4]:

- Статистический подход, в котором для предоставления характеристик текстурных изображений используется множество признаков.
- Структурное моделирование позволяет рассматривать текстуры как двумерные образы, состоящие из множества примитивов или подобразов, которые расположены в соответствии с некоторым правилом.
- Стохастическое моделирование предполагает, что текстура – это реализация стохастического процесса, характеризующегося некоторыми параметрами. Применение этого подхода позволяет получить хорошие результаты для генерации реалистичных натуральных текстурных изображений при использовании марковских случайных полей [5].

Для классификации текстурных изображений будем применять модель изображения как реализацию случайного марковского поля, то есть стохастический подход к анализу текстур. Большой вклад в развитие этой модели внёс Харалик, который ввёл статистический и структурный подходы к описанию текстуры [6], а также предложил использовать признаки на основе матрицы взаимного распределения вероятности. Предложенная матрица является матрицей смежности уровня серого [1], и описывает пространственные связи пар яркостей элементов текстуры.

## 2. Представление изображения согласно модели марковского случайного поля

Введение стохастических моделей или моделей случайных полей привели к разработке алгоритмов восстановления изображений, сегментации, текстурного моделирования и классификации. В частности, марковские случайные поля весьма полезны как для моделирования пространственных взаимосвязей, так и для исследования стохастического взаимодействия между наблюдаемыми величинами, в том числе при анализе медицинских изображений и интерпретации изображений дистанционного зондирования [7].

Теория марковского случайного поля (МСП) обеспечивает удобный и последовательный способ для моделирования связи между зависимыми сущностями, такими как пиксели изображения и коррелированные признаки. Удобство достигается за счет характерного взаимного влияния, среди таких объектов, используя условные распределения МСП. Практическое использование модели марковского случайного поля получили благодаря теореме о эквивалентности между МСП и распределением Гиббса, которая была введена Хаммерсли и Клиффордом в 1971 году. [8]. Это происходит потому, что совместное распределение требуется в большинстве приложений, но вывод совместного распределения из условного оказывается очень трудным для МСП. Теорема эквивалентности марковских случайных полей и Гиббса указывает на то, что совместное распределение МСП является простой формой распределения Гиббса.

Мы будем рассматривать модель Гауссовского марковского случайного поля (ГМСП), которая является частным случаем МСП, где значение пиксела в позиции  $(i, j)$  статистически зависит от соседних пикселей. Это означает, что модель учитывает пространственные взаимодействия внутри каждого цветового компонента и взаимодействия между различными компонентами [9]. Изображение представлено на прямоугольной решетке  $S=M*N$  с числом полос  $p$ .

Пусть  $X(i, j) = [x_1(i, j)x_2(i, j) \dots x_p(i, j)]$  представляет собой вектор в текстурном регионе  $R$ . Предполагается, что вектор в позиции  $(i, j)$  представляет собой линейную комбинацию из цветовых составляющих соседних пикселей и аддитивного гауссова шума. Пусть  $\mu_1, \mu_2 \dots \mu_p$  обозначают средние интенсивности цвета, а  $e_1, e_2 \dots e_p$  – пространственное взаимодействие пикселей и  $v_{xy}$  – ожидаемое значение  $e_x e_y$ .  $x, y$  принимают значения от 1 до  $p$ . Пусть  $\phi_{xy}$  – соответствующие параметры модели и  $\sum$  – матрица смежности.

Пространственное взаимодействие цветовых пикселей определяется как:

$$e_1(i, j) = (x_1(i, j) - \mu_1) - \sum_{(m, n) \in N_{11}} \phi_{11}(m, n)(x_1(i + m, j + n) - \mu_1) \\ - \sum_{(m, n) \in N_{12}} \phi_{12}(m, n)(x_2(i + m, j + n) - \mu_2) - \dots \\ - \sum_{(m, n) \in N_{1p}} \phi_{1p}(m, n)(x_p(i + m, j + n) - \mu_p)$$

Точно также оно определяется для  $e_2(i, j), e_3(i, j) \dots e_p(i, j)$ . Обобщенная формула задается как:

$$e_k(i, j) = (x_k(i, j) - \mu_k) - \sum_{(m, n) \in N_{k1}} \phi_{k1}(m, n)(x_1(i + m, j + n) - \mu_1) \\ - \sum_{(m, n) \in N_{kp2}} \phi_{kp2}(m, n)(x_2(i + m, j + n) - \mu_2) - \dots \\ - \sum_{(m, n) \in N_{kp}} \phi_{kp}(m, n)(x_p(i + m, j + n) - \mu_p), k = \overline{1, p}$$

где  $N_{xy}$  обозначают соседние пиксели. Если  $x=y$ , то соседние пиксели будут соответствовать той же цветовой составляющей. В противном случае, соседние пиксели будут от других компонент.

Матрица смежности задаётся следующим образом:

$$\sum = \begin{pmatrix} v_{11} & v_{12} & \dots & v_{1p} \\ v_{21} & v_{22} & \dots & v_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ v_{p1} & v_{p2} & \dots & v_{pp} \end{pmatrix}$$

Ожидаемое значение  $v_{kl}$  представляется как:

$$v_{kl} = E[e_k e_l] = \frac{1}{M_R} \sum_{(i, j) \in R} e_k(i, j) e_l(i, j)$$

Описав все термины, функция плотности вероятности  $X(i, j)$  получается равной:

$$P(X(i, j)|R) = \frac{1}{((2\pi)^p |\Sigma|)^{\frac{1}{2}}} \exp\left\{-\frac{1}{2} (e_1(i, j)e_2(i, j) \dots e_p(i, j)) \sum (e_1(i, j)e_2(i, j) \dots e_p(i, j))^t\right\}$$

### 3. Выбор информативной окрестности

Винклер в работе «Анализ изображений, случайные поля и динамические методы Монте-Карло» [10] пишет о восстановлении изображений и моделировании текстур с помощью случайных полей, подробно рассматривает финитные случайные поля, в том числе марковские, применяет методы Монте-Карло на цепях Маркова. Чохен на примере задачи автоматизации контроля текстильных тканей [11] решает задачу обнаружения и локализации различных видов дефектов, для чего использует гауссовское марковское случайное поле и некаузальную окрестность. Ковтун в статье [12] предлагает модель изображения, особенность которой состоит в том, что сегментация и каждая текстура задаются независимыми случайными полями. В его работе делается попытка выделить проблему текстурной сегментации из общего класса задач генерирования и моделирования марковских случайных полей.

Таким образом, в работах [3, 5, 7-12] говорится о использовании модели марковского случайного поля для описания и генерации текстурных изображений. Одним из параметров описываемой модели является распределение вероятностей яркости соседних пикселей. При этом, при выборе соседних пикселей, в работах, посвященных этой тематике, используется некаузальная окрестность (рис. 1).




Рис. 1. Пример окрестностей: (а) — некаузальная, (б) — каузальная.

В работе предлагается новый способ выбора информативной окрестности для описания характерных особенностей текстуры.

Описание основных этапов технологии выбора информативной окрестности можно представить в виде следующего алгоритма:

1. Выбираем исходные данные: форму окрестности, набор признаков, рассчитанных по окрестности и разделённые на классы текстурные изображения.
2. Производим расчёт признаков по выбранной окрестности для каждого изображения. Формируем исходную выборку.
3. Рассчитываем индивидуальные критерии разделимости для каждого признака [13]. Проводим оценку информативности признаков, основываясь на значении критерия [14].
4. Исключаем из исходной выборки признаки с низким значением критерия разделимости.
5. Исключаем из окрестности пиксели, соответствующие неинформативным признакам.

Таким образом, оставшиеся пиксели составляют информативную окрестность.

Экспериментальные исследования технологии проводились на базе текстурных изображений «Kylberg Texture Dataset v. 1.0» [15]. Рассмотрим применение технологии к двум классам изображений rice1 и rice2 выбранной базы. Примеры рассматриваемых изображений представлены на рисунке 2.




Рис. 2. Пример изображений: (а) — rice1, (б) — rice2.

Для различения классов текстурных изображений были использованы статистические признаки, рассчитанные по формуле:

$$\lambda(\Delta x, \Delta y, n) = \frac{\sum |f(x, y) - f(x + \Delta x, y + \Delta y)|^n}{N},$$

где  $f$  – функция яркости изображения,  $N$  – количество пикселей изображения. Для исследования использовались признаки  $\lambda$ , рассчитанные при  $\Delta x, \Delta y = 0, \pm 1, \pm 2$ ,  $n = 1, 2, 3$ . Вследствие того, что признаки являются симметричными, использовалась каузальная окрестность.

Были рассчитаны индивидуальные критерии разделимости по каждому признаку (рис. 3). Для выборки, состоящей из  $n$  элементов, разделённых на  $g$  классов и содержащей  $p$  признаков, критерий разделимости рассчитывается по следующим формулам:

$$J = \text{tr}((T)^{-1}B),$$

где  $T = B + W$ .

$B$  – матрица межгруппового рассеяния, элементы которой рассчитываются по формуле:

$$b_{ij} = \sum_{k=1}^g n_k (\bar{x}_{ik} - \bar{x}_i)(\bar{x}_{jk} - \bar{x}_j), i, j = \overline{1, p},$$

$W$  – матрица внутригруппового рассеяния, элементы которой рассчитываются по формуле:

$$w_{ij} = \sum_{k=1}^g \sum_{m=1}^{n_k} (x_{ikm} - \bar{x}_{ik})(x_{jkm} - \bar{x}_{jk}), i, j = \overline{1, p},$$

$x_{ikm}$  – значение  $i$ -ого признака для  $m$ -го элемента в классе  $k$ ,

$\bar{x}_{ik} = 1/n_k \sum_{m=1}^{n_k} x_{ikm}$  – среднее значение  $i$ -ого признака в классе  $k$ ,

$\bar{x}_i = 1/n \sum_{k=1}^g n_k \bar{x}_{ik}$  – среднее значение  $i$ -ого признака по всем классам,  $n_k$  – число элементов в классе  $k$ .

Чем больше значение критерия – тем больше разделимость классов.

0,74	0,77	0,82	0,77	0,55
0,58	0,74	0,85	0,61	
0,58	0,61			
0,53				

Рис. 3. Среднее значение критерия разделимости.

После расчёта индивидуальных критериев разделимости были исключены признаки с низким значением критерия. Анализ полученного признакового пространства, позволил сделать вывод о том, какие из соседних пикселей несут в себе информацию об особенностях текстур (информационные пиксели выделены цветом на рис.3). Из окрестности были исключены пиксели, соответствующие неинформативным признакам (рассчитанным при  $(\Delta x = 2, \Delta y = 2)$ ,  $(\Delta x = -2, \Delta y = 1)$ ,  $(\Delta x = 1, \Delta y = 1)$ ,  $(\Delta x = -2, \Delta y = 0)$ ,  $(\Delta x = -1, \Delta y = 0)$ ,  $(\Delta x = -2, \Delta y = -1)$ ). Таким образом, мы смогли получить информативную окрестность новой формы. Модифицированная окрестность для исследуемых классов представлена на рисунке 4.

○	○	○	○	
	○	○		
		●		

Рис. 4. Модифицированная окрестность.

Для исследования эффективности разработанной технологии была проведена оценка качества выбранной окрестности. Оценка проводилась путём вычисления ошибки кластеризации на основе алгоритма k-means, где в качестве начальных условий использовались центры исходных классов [16]. Под ошибкой кластеризации понимается доля изображений, которая была отнесена не к своему классу. Ошибка кластеризации в случае использования признаков, рассчитанных по каузальной окрестности, составила 0,21, по модифицированной 0,19, что подтверждает информативность модифицированной окрестности.

В таблице 1 приведены значения ошибки кластеризации в случае использования признаков, рассчитанных с использованием каузальной и модифицированной окрестности, для различения других классов изображений из выбранной базы текстур.

Таблица 1. Значения ошибки кластеризации при использовании различных окрестностей

Сравниваемые классы	Каузальная окрестность	Модифицированная окрестность
blanket1 и canvas1	0,03	0,03
scarf1 и scarf2	0,18	0,16
linseeds и sesameeds	0,46	0,40

На рисунке 5 приведены средние значения критериев разделимости для случаев, рассмотренных в таблице 1, цветом выделены модифицированные окрестности.

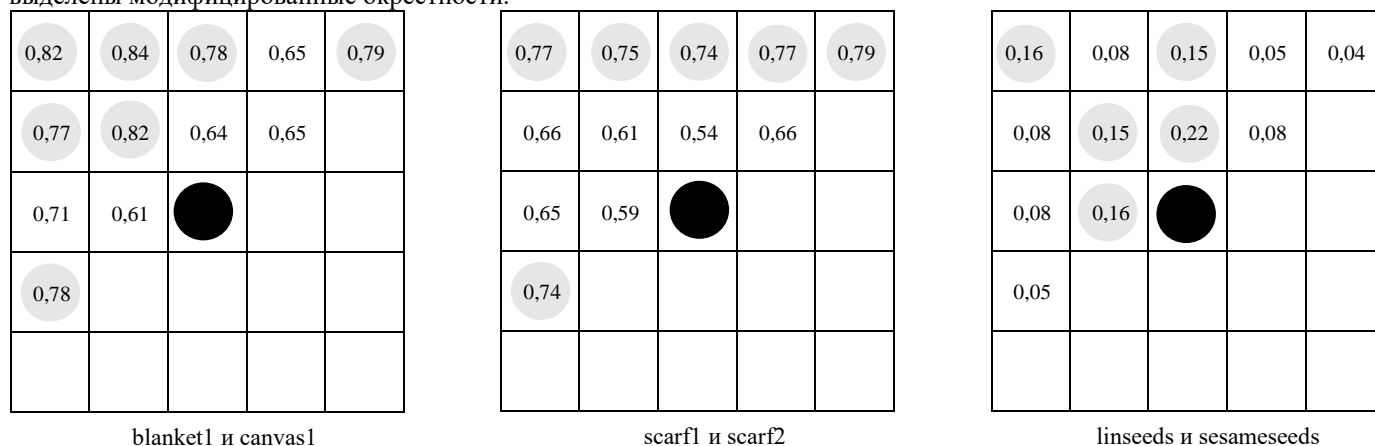


Рис. 5. Средние значения критерия разделимости для различных классов.

По таблице 1 видно, что значение ошибки кластеризации при использовании модифицированной окрестности не превышает значение ошибки при использовании каузальной окрестности, что говорит о информативности полученных окрестностей, а, следовательно, эффективности предложенной технологии.

#### 4. Заключение

В работе представлена технология выбора информативной окрестности, которая показала свою эффективность для рассматриваемых классов текстурных изображений. За счёт сокращения количества соседних пикселей, было уменьшено пространство признаков и снижена ошибка кластеризации. Предложенная технология может найти применение в задачах моделирования текстурных изображений, где для вычисления параметров модели марковского случайного поля используется окрестность.

#### Благодарности

Работа выполнена при частичной поддержке Министерства образования и науки РФ в рамках реализации мероприятий Программы повышения конкурентоспособности СГАУ среди ведущих мировых научно-образовательных центров на 2013–2020 годы; грантов РФФИ № 15-29-03823, № 15-29-07077, № 16-41-630761, №17-01-00972; программы № 6 фундаментальных исследований ОНТИ РАН «Биоинформатика, современные информационные технологии и математические методы в медицине» 2017 г.

#### Литература

1. Haralick, R. M. Statistical and structural approaches to texture / R. M. Haralick // Proceedings of the IEEE.— 1979.— Vol. 67, no. 5.—P. 786–804.
2. Haindl, M. Texture synthesis / M. Haindl // CWI Quarterly. — 1991. —Vol. 4.— P. 305–331.
3. Dubes, R. C. Random field models in image analysis / R. C. Dubes, A. K. Jain // Journal of Applied Statistics.— 1989.— Vol. 16, no. 2.— P. 131–164.
4. Ahuja, N. Mosaic models for textures / N. Ahuja, A. Rosenfeld // IEEE Transactions on Pattern Analysis and Machine Intelligence. — 1981. — Vol. PA MI 3.— P. 1–10
5. Пластинин, А.И. Метод формирования признаков текстурных изображений на основе Марковских моделей, Дис... кан. тех. наук, Самара, (2012).
6. Харалик Р. М. Статистический и структурный подходы к описанию текстур / Р.М. Харалик // ТИИРЭ. – 1979. - № 5. – С. 98–118.
7. Li, Stan Z. Markov Random Field in Image Analysis / Stan Z. Li. – Springer-Verlag, 2009. – 362 p.
8. Hammersley, J. M. and P. Clifford, Markov field on finite graphs and lattices, unpublished, 1971
9. Mridula, J. Feature Based Segmentation of Colour Textured Images using Markov Random Field Model, Master of Technology, Odisha, India, (2011)
10. Винклер, Г. Анализ изображений, случайные поля и динамические методы Монте-Карло / Г. Винклер // Новосибирск: Филиал "Гео"Издательства СО РАН. – 2002. – 343 с.
11. Cohen, F.S. Automated Inspection of Textile Fabrics Using Textural Models / F. S. Cohen, Z. Fan, and S. Attali // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 1991. - Vol. 8, no. 13. – pp. 803-808.
12. Ковтун, И.В. Текстура сегментация изображений на основе марковских случайных полей / И.В. Ковтун // Управляющие системы и машины. – 2003. – № 4. –С. 46-55.
13. Фукунага, К. Введение в статистическую теорию распознавания образов / К. Фукунага // Москва: Наука. – 1979. – 270 с.
14. Biryukova, E. Development of the effective set of features construction technology for texture image classes discrimination / E. Biryukova, R. Paringer, A.V. Kupriyanov // CEUR Workshop Proceedings. – 2016. – Vol.1638. – P. 263-269 DOI: 10.18287/1613-0073-2016-1638-357-363
15. Kylberg, G. Kylberg Texture Dataset v. 1.0 [Electronic resource] / G. Kylberg. 2014. URL: <http://www.cb.uu.se/~gustaf/texture> (дата обращения 18.12.2016).
16. Мандель, И. Д. Кластерный анализ / И.Д. Мандель // Москва: Финансы и Статистика. – 1988.